

SVEUČILIŠTE U ZAGREBU
PRIRODOSLOVNO-MATEMATIČKI FAKULTET
MATEMATIČKI ODSJEK

Magdalena Šimac

ODREDNICE PRORAČUNSKE
TRANSPARENTNOSTI HRVATSKIH
GRADOVA

Diplomski rad

Voditelj rada:
Prof. dr. sc. Katarina Ott

Zagreb, 2017.

Ovaj diplomski rad obranjen je dana _____ pred ispitnim povjerenstvom u sastavu:

1. _____ , predsjednik

2. _____ , član

3. _____ , član

Povjerenstvo je rad ocijenilo ocjenom _____.

Potpisi članova povjerenstva:

1. _____

2. _____

3. _____

Hvala mami i sestri što su me trpjele sve vrijeme studiranja.

Mama, hvala ti jer si mi svojim primjerom pokazala da nema odustajanja kad je najteže!

Sadržaj

1. UVOD.....	2
2. PREGLED EMPIRIJSKE I TEORIJSKE LITERATURE O PRORAČUNSKOJ TRANSPARENTNOSTI.....	5
2.1. Porezi i proračunska transparentnost	7
2.2. Broj stanovnika i proračunska transparentnost	8
2.3. (Re)izbor gradonačelnika i proračunska transparentnost	8
2.4. Visokoobrazovano stanovništvo i proračunska transparentnost	9
3. PODATCI I METODOLOGIJA	10
3.1. Podatci.....	10
3.2. Metodologija istraživanja.....	12
3.2.1. Poissonova regresija	13
3.2.2. Interpretacija parametara Poissonove regresije	15
3.2.3. Testiranje prilagodbe Poissonovog modela podacima	16
3.2.4. Test disperzije.....	18
4. EMPIRIJSKA ANALIZA	19
4.1. Deskriptivna statistika.....	19
4.2. Poissonova regresija.....	28
4.3. Testiranje modela	33
4.4 Test disperzije	35
5. ZAKLJUČAK.....	36
6. LITERATURA	38
Dodatak.....	41
Sažetak	46
Summary.....	47
Životopis	48

1. UVOD

U demokratskim društvima pristup informacijama i transparentnost mogu se smatrati ljudskim pravima. Građani imaju pravo znati odnosno na vrijeme biti informirani o postupcima političkih vlasti te o motivaciji tih postupaka. Transparentnost je važna ne samo zbog povećanja efikasnosti iskorištavanja javnih resursa, već i zbog povećanja povjerenja između političkih tijela i građana, a blisko je povezana i s političkom odgovornošću. Transparentnost javnih tijela valja zahtijevati i kako bi se nakon objave relevantnih informacija moglo pratiti i vrednovati njihov rad. No, dobra dostupnost informacija, u konačnici, ne mora nužno voditi i smanjenju korumpiranosti vlasti.¹

Kako bi ispunila ciljeve globalne inicijative *Partnerstvo za otvorenu vlast*², kao njena članica od 2011., Republika Hrvatska (RH) obećala je provoditi mjere kojima bi, između ostalog, poboljšala dostupnost sadržaja lokalnih proračuna građanima i javnosti, među koje spadaju i gradski proračuni.³

Postoji već bogata strana i domaća literatura koja se bavi proračunskom transparentnošću lokalnih jedinica – njenim mjerenjima i utvrđivanjem njenih odrednica. Oslanjajući se na takvu literaturu – koja će se detaljnije obraditi niže u tekstu – u ovom se radu analizira veza proračunske transparentnosti hrvatskih gradova i izabranih varijabli.

Cilj rada jest ispitati imaju li izabrane političke, ekonomske i socijalno-kulturološke varijable značajan utjecaj na proračunsku transparentnost (dalje u tekstu: transparentnost) hrvatskih gradova. U tu će se svrhu koristiti niže u tekstu obrazložena metodologija, testirati odabrane hipoteze i analizirati dobiveni rezultati. Pokažu li se neke od tih varijabli značajnima, može se doći do mogućih uzroka zašto su neki gradovi transparentniji od drugih i obrnuto.

¹ Prema Bellver i Kaufmann [1]

² *Partnerstvo za otvorenu vlast* je multilateralna inicijativa čiji je cilj osigurati konkretan napredak na području transparentnosti i otvorenosti rada tijela javnih vlasti, uključivanja i osnaživanja građana i civilnoga društva, borbe protiv korupcije te korištenja novih tehnologija za poboljšanje kvalitete usluga koje javna uprava pruža građanima. (vidi [28])

Konkretno, ispitat će se kako na transparentnost utječu sljedeće varijable: (i) prihod od poreza i prireza porezu na dohodak po zaposlenom stanovniku, (ii) broj stanovnika, (iii) reizbor gradonačelnika, te (iv) udio visokoobrazovanih osoba u ukupnoj populaciji. Primjerice, testirat će se ima li veći broj stanovnika određenog grada utjecaj na njegovu veću transparentnost. Kao uzorak uzima se 127 hrvatskih gradova, bez grada Zagreba čije se vrijednosti spomenutih varijabli izrazito razlikuju u odnosu na iste vrijednosti kod ostalih gradova. Podatci za odabrane varijable uzeti su iz različitih godina, od 2011. do 2016., a zašto su baš one izabrane, objašnjeno je u nastavku.

Veliki dio gradskih poreznih prihoda čini porez na dohodak te prirez poreza na dohodak (dalje u tekstu: porez i prirez). Onoga tko ih plaća, a prvenstveno se misli na zaposlene građane, trebalo bi zanimati na koji će način grad raspolagati s tako prikupljenim sredstvima. Svako povećanje poreza i prireza građani primijete prilikom primanja plaće, pogotovo ako im je ona jedini izvor osobnih prihoda. Stoga, što su porez i prirez veći (zaposleni) građani bi se trebali pitati zašto su veći, odnosno je li se taj novac i na neki drugi način mogao prikupiti u gradski proračun, te kako uopće izgleda gradski proračun.

Gradovi s većim brojem stanovnika često su razvijeniji od onih s manjim. Razvijenost može značiti i veće proračunske prihode, bolju IT infrastrukturu, više zaposlenih u gradskoj upravi, bolji pristup informacijama, pa posljedično, i veću proračunsku transparentnost.

Svaki gradonačelnik, između ostaloga, sastavlja i prijedlog proračuna. Kako bi bio ponovno izabran na lokalnim izborima, trebao bi u trenutnom mandatu paziti i kakvu politiku vodi i kako raspolaže s financijskim sredstvima. Nezadovoljni građani bi u slučaju lošeg upravljanja, vjerojatno, više glasova dali ostalim kandidatima, što bi moglo rezultirati promjenom vodstva (gradonačelnika). Posljedično, i očekivanjem da će novoizabrani gradonačelnik bolje upravljati gradom, što bi, pak, trebalo rezultirati i većom proračunskom transparentnošću.

Od visokoobrazovanog čovjeka očekuje se da kritičnije pristupa pojedinoj temi, više analizira i preispituje životne situacije. Pod uvjetom da ga zanima politika, pa onda i lokalna politika, možda ga zanima i kako njegov grad funkcionira, odakle crpi sredstva za

financiranje i kako raspolaže tim sredstvima. Stoga se postavlja pitanje – utječe li na transparentnost broj visokoobrazovanih osoba u ukupnom stanovništvu?

U radu se, dakle, ispituje da li na proračunsku transparentnost hrvatskih gradova pozitivno utječu:

- veći prihod od poreza i prireza na dohodak po zaposlenom stanovniku,
- promjena gradonačelnika na izborima,
- veći udio visokoobrazovanih osoba u ukupnom broju stanovnika grada,
- veći broj stanovnika grada.

Konstruira se nekoliko različitih modela s različitim izborom nezavisnih varijabli – neki sadrže sve četiri izabrane varijable, a neki samo jednu ili dvije. Za ispitivanje utjecaja pojedine varijable na transparentnost koristi se Poissonova regresija. Regresijska analiza ukazuje da na proračunsku transparentnost hrvatskih gradova statistički značajno utječe jedino udio visokoobrazovanih osoba u ukupnom broju stanovnika, te da su gotovo sve nezavisne varijable međusobno (osrednje) pozitivno korelirane, što je možda utjecalo na same rezultate regresije provedene na različitim modelima.

U poglavljima koja slijede prikazat će se, redom, pregled empirijskih istraživanja i pregled teorijske literature o transparentnosti, objašnjenje metodologije koja se koristi u ovom radu, analiza dobivenih rezultata i zaključak.

2. PREGLED EMPIRIJSKE I TEORIJSKE LITERATURE O PRORAČUNSKOJ TRANSPARENTNOSTI

Prije testiranja utjecaja izabranih varijabli, nudi se pregled odabranih članaka koji su se bavili traženjem povezanosti različitih ekonomskih, socijalno-kulturoloških, antropoloških i ostalih varijabli s proračunskom transparentnošću.

Mnogi politolozi, ekonomisti i sociolozi ističu važnost proračunske transparentnosti. Ona je važan sastojak za efektivnu političku kontrolu i nadgledanje javnog sektora tvrde Guillamón, Bastida i Benito [12]. Proračunska transparentnost bitna je kako bi se na vrijeme dobila informacija o proračunu, kako bi građani mogli bolje razumjeti političke odluke, saznati više o politici financiranja unutar država, regionalnih ili lokalnih jedinica (pa tako i gradova) te smanjiti nepovjerenje prema vladajućim strukturama. Prema Mathesonu [12], proračunska transparentnost zahtjeva da sve relevantne fiskalne informacije budu sistematično i na vrijeme izložene i dane u javnost. Informacija je ključna stavka za učinkovita i dobro funkcionirajuća ekonomska i politička tržišta. Što je više informacija, to se bolje mogu analizirati, nadzirati i vrednovati događaji značajni za ekonomsku i socijalnu sigurnost ljudi (vidi [13]). Alesina i Perotti [1] tvrde da manjak transparentnosti pomaže stvaranju konfuzije i dvosmislenosti (pravog) stanja javnih financija tako da se skriva što je više moguće sadašnjih i budućih poreznih tereta, prenaglašavaju prednosti trošenja ili, primjerice, podcjenjuje važnost i veličina trenutnih i budućih vladinih obveza. Isti autori ukazuju na različite "trikove", u kontekstu netransparentnosti, koje političari koriste. Primjerice, optimistična predviđanja ključnih makroekonomskih varijabli (rast, inflacija, nezaposlenost, kamatne stope) kako bi se precijenili prihodi i podcijenili rashodi ili, s druge strane, optimistična predviđanja posljedica novih politika (npr. novih reformi) na proračunsku ravnotežu. Manjak transparentnosti često je povezan s korupcijom vladajućih, spominju Guillamon, Benito i Bastida [12], dok Sharman i Chaikin [12] ukazuju na to da je korupcija najvažniji financijski problem u većini zemalja u razvoju, te, možda, najveća prepreka ekonomskom

razvoju. Iz navedenog slijedi jasna potpora povećanju razine transparentnosti na svim razinama vlasti. Većina studija i radova otkrivaju pozitivne učinke fiskalne transparentnosti na javnu i političku odgovornost, no relativno mali broj studija ispituje što točno određuje fiskalnu transparentnost vlada, napominju Ma i Wu [14].

Različiti autori različito definiraju i/ili koriste različite metode mjerenja transparentnosti. Guillamon, Benito i Bastida [12] koriste indeks transparentnosti definiran pomoću odgovora na upitnik poslan na adrese sto najvećih španjolskih lokalnih jedinica, a koji, između ostalog, obuhvaća i informacije o, kako oni to zovu, financijskoj transparentnosti. Pitanja koja se tiču financijske transparentnosti ima dvadeset i podijeljena su u tri grupe: računovodstvo i proračun, transparentnost prihoda i troškova, te transparentnost dugova. Svako pitanje daje informaciju o objavljivanju odgovarajuće informacije odnosno dokumenta. Za svako pitanje lokalna jedinica dobiva 2 boda ukoliko je pojedina informacija ili pojedini dokument objavljen na njejoj web stranici, 1 i pol bod ako su informacija/dokument objavljeni na stranici TI-Spain⁴, ali ne i na lokalnoj web stranici, zatim 1 bod ukoliko je informacija/dokument objavljen u digitalnoj ili fizičkoj publikaciji s ISSN-om ili ISBN-om, ili objavljena u službenom biltenu, a 0 bodova ako informacija/dokument nije objavljen u nijednoj publikaciji, ili sama lokalna jedinica nije odgovorila na pitanje.

Ma i Wu [14], pak, uzimaju indeks tzv. fiskalne transparentnosti koji se temelji na 113 informacija/pitanja zatraženih od kineskih provincija, a koje se sastoje od 66 stavki vezanih uz izvještaje provincijskih vlada, 30 stavki vezanih uz izvještaje o socijalnom osiguranju, te 17 stavki vezanih za izvještaje poduzeća u provincijskom vlasništvu. Savjesnost svake provincijske vlade procijenjena je na temelju brzine i kvalitete odgovora na navedena pitanja o fiskalnoj transparentnosti, a bilo je moguće dobiti od 0 do 50 bodova. Dok se za svaku pojedinu stavku/odgovor na odgovarajuće pitanje moglo dobiti 10 bodova ukoliko je sama informacija bila dovoljno sveobuhvatna. Ukupno je bilo moguće ostvariti od 0 do 1180 bodova za informacije o 113 stavki. Indeks fiskalne transparentnosti je, onda, konstruiran na temelju svega spomenutog, uz mogućnost dobivanja od 0 do 1180 bodova.

⁴ Organizacija Transparency International Spain

Kao što se vidi iz ovih primjera, ne postoji jedna definicija proračunske transparentnosti ni jedinstveni način njenog mjerenja, već razni autori na različite načine shvaćaju transparentnost odnosno uzimaju različite podatke kako bi procijenili transparentnost određenih lokalnih jedinica ili određenih zemalja ovisno o svom istraživanju. Većina se autora više oslanja na kvantitetu ili dostupnost informacija, dok rijetki uzimaju obzir i njihovu kvalitetu.

Debreceeny, Gray i Rahman [9] naglašavaju prednosti internetskog izvještavanja, a to su niska cijena, brzina i fleksibilnost formata samih izvještaja. Zbog toga se internetsko izvještavanje sve više koristi u radovima i studijama temeljenim na proračunskim dokumentima. Treba spomenuti i brzi razvitak informacijskih i komunikacijskih tehnologija posljednjih nekoliko godina, što iz ekonomskih, što iz društvenih razloga. Perez i dr. [21] ističu kako posljednjih godina termin elektronička vlada (engl. *e-government*) koji se odnosi na pokušaje javnih inicijativa da omoguće jednostavniji pristup javnim uslugama putem spomenutih tehnologija, prvenstveno putem web stranica, jasno potvrđuje taj trend.

U nastavku poglavlja prikazat će se pregled literature s fokusom na varijable koje će biti korištene u empirijskoj analizi. To su: prihodi od poreza i prireza na dohodak, broj stanovnika, reizbor gradonačelnika i udio visokoobrazovanog stanovništva u ukupnoj populaciji.

2.1. Porezi i proračunska transparentnost

Prva varijabla, za koju ćemo pokušati pronaći vezu s proračunskom transparentnošću hrvatskih gradova, jest prihod od poreza i prireza porezu na dohodak po zaposlenom stanovniku. Drugi autori, u svojim studijama, ne koriste ovako definiranu varijablu, ali imaju slične varijable koje se odnose na poreze. Ferejohn [12] upućuje na to da su veći porezi i transferi povezani s višom razinom fiskalne transparentnosti, pri čemu porezni obveznici traže veću transparentnost kako bi mogli podržati političare da skupljaju i

upravljaju većim iznosima finansijskih sredstava. Guillaumon, Benito i Bastida [12] pronalaze da prihodi od poreza po stanovniku pozitivno utječu na finansijsku transparentnost. Obzirom da su lokalne jedinice s višim porezima transparentnije, isti autori tvrde da vladajući unutar takvih jedinica ne iskorištavaju prednost tzv. fiskalne iluzije ili tzv. principal-agent problema. Teorija fiskalne iluzije se, između ostalog, temelji na nesposobnosti poreznih obveznika da uvide i shvate punu cijenu javnih dobara i usluga, dok prema principal-agent teoriji manjak transparentnosti omogućuju političarima (agentima) da rade za svoje osobne interese, koji često nisu istovremeno i interesi njihovih glasača (principala) (vidi [2]).

2.2. Broj stanovnika i proračunska transparentnost

Iduća varijabla je ukupan broj stanovnika odnosno veličina populacije. Guillaumon, Bastida i Benito [12] zaključuju da populacija (prirodni logaritam od populacije) ima pozitivan i značajan utjecaj na proračunsku transparentnost. Kao prvo, veće lokalne jedinice raspolažu s većim prihodima, stoga su pod većim pritiskom da budu odgovornije i paze kako će raspolagati tim prihodima, odnosno da budu transparentnije. S druge strane, transparentnost zahtjeva pogodnu infrastrukturu, koja uključuje dovoljno materijalnih sredstava i ljudi. Lokalne jedinice s većom populacijom (ali istovremeno i većim dohotkom po stanovniku) omogućuju lakši i jednostavniji pristup finansijskim podacima putem svojih web stranica, zaključuju Styles i Tennyson [27]. Kao objašnjenje ističu povećan pristup i puno veće korištenje interneta u gradovima s većim brojem stanovnika.

2.3. (Re)izbor gradonačelnika i proračunska transparentnost

Reizbor pruža informacije o tome je li prethodni gradonačelnik ostao na svojoj poziciji nakon posljednjih izbora. Alt i Lowry [4] pokazuju da proračunska transparentnost nema direktnog, statistički značajnog utjecaja na ponovni izbor guvernera, ali, između ostalog,

pronalaze jasan dokaz da povećana transparentnost smanjuje negativan učinak rasta poreza na ponovni izbor istog guvernera. Alt i Lassen [3] pronalaze da su politički predstavnici unutar prilično kompetitivnog izbornog sustava motivirani ostvariti visoku razinu fiskalne transparentnosti. Također, objašnjavaju da politički kompetitivnije zemlje odnosno, općenitije, zemlje s razvijenim pravnim sustavom i razvijenim političkim/predsjedničkim sustavom imaju transparentnije institucije.

2.4. Visokoobrazovano stanovništvo i proračunska transparentnost

Gandia i Archidona [11] koriste udio visokoobrazovanih stanovnika u ukupnoj populaciji španjolskih gradova. Oni dokazuju da otvorenost i dostupnost proračuna putem web stranica španjolskih gradskih vijeća ovisi o udjelu fakultetski obrazovanih stanovnika i dodatnoj varijabli koja pokazuje udio domova s kompjuterom i internetskim pristupom. Serrano-Cinca i dr. [25] koriste varijablu koju nazivaju razina obrazovanja, a mjere je prosječnim brojem godina obrazovanja. Iako njihovi podatci indiciraju povezanost spomenute varijable i dostupnosti informacija koje se, između ostalog, tiču proračuna (engl. *e-disclosure*), razina odnosno interval pouzdanosti je poprilično nizak.

3. PODATCI I METODOLOGIJA

Kao što je spomenuto u prethodnim poglavljima, varijable koje će se promatrati su: prihod od poreza i prireza porezu na dohodak po zaposlenom stanovniku, broj stanovnika, reizbor gradonačelnika, te udio visokoobrazovanih osoba. One će biti nezavisne varijable, a proračunska transparentnost zavisna varijabla. Potonju varijablu izračunali su Ott, Bronić, Petrušić i Stanić [19].

Grad Zagreb izuzet je iz analize jer se po mnogim parametrima poprilično razlikuje od ostalih gradova. U prvom dijelu ovog poglavlja detaljno se opisuje kako se konstruirala pojedina varijabla i koje su njezine temeljne značajke, a u drugom dijelu metode koje će se koristiti u empirijskom dijelu rada, tj. Poissonova regresija.

3.1. Podatci

Kako bi se vidjelo kakva je transparentnost pojedinog grada, bitno je odrediti način na koji će se ona mjeriti. Ovaj rad koristit će metodologiju Ott, Bronić, Petrušić i Stanić [19], gdje se proračunska transparentnost svih lokalnih jedinica u RH (općina, gradova i županija) mjeri brojem ključnih proračunskih dokumenata objavljenih na njihovim službenim mrežnim stranicama, a to su godišnje izvršenje proračuna za 2014.; polugodišnje izvršenje proračuna za 2015.; prijedlog proračuna za 2016.; izglasani proračun za 2016. i proračun za građane za 2016. Budući da se promatra dostupnost pet proračunskih dokumenata, razina transparentnosti može iznositi od nula do pet.

Sukladno inicijalnom popisu nezavisnih varijabli sada će se prikazati izvori i osnovne informacije temeljem kojih su konstruirane za potrebe empirijske analize. Prikazat ćemo prvo ekonomske (porez i prirez na dohodak po zaposlenom), zatim socio-kulturološke (broj stanovnika i udio visokoobrazovanih u ukupnoj populaciji) te na kraju i političku varijablu (reizbor).

Podatci o prihodima temeljem poreza i prireza na dohodak preuzeti su s web stranica Ministarstva financija RH [17], točnije ostvarenja proračuna 2014. za svaki hrvatski grad. Unutar proračuna pojedinog grada promatrala se stavka „Porez i prirez na dohodak“ čiji se najveći dio, preko 90 posto, odnosi na porez i prirez na dohodak od nesamostalnog rada. Tome se dodaju porez i prirez na dohodak od samostalne djelatnosti, od imovine i imovinskih prava, od kapitala, po godišnjoj prijavi, utvrđenog u postupku nadzora za prethodne godine, te oduzme povrat poreza i prireza na dohodak po godišnjoj prijavi. Tako dobiven ukupan iznos poreza i prireza na dohodak podijeljen s brojem zaposlenih stanovnika pojedinog grada rezultira varijablom koja će se koristiti u kasnijem testiranju hipoteza.

Podatci za socio-kulturološku varijablu – broj stanovnika – dobiveni su iz popisa stanovništva 2011. [23]. To su ujedno i najaktualniji podatci, ali treba uzeti u obzir da se u međuvremenu ukupan broj stanovnika države, pa i gradova smanjio, i prema zadnjim procjenama iz 2015. taj je broj za barem 77 tisuću manji nego što je bio 2011. [24].

Konstrukcija varijable udio visokoobrazovanih u ukupnoj populaciji podrazumijevala je dva koraka. U prvom, iz popisa stanovništva 2011., preuzeti su podatci o broju visokoobrazovanih osoba, dok se u drugom koraku taj broj podijelio s već spomenutom varijablom broja stanovnika i pomnožio sa 100. Pod visokoobrazovanim osobama misli se na one koje su završile fakultet (stručni studij, sveučilišni studij ili nešto više).

Posljednja, politička varijabla – reizbor gradonačelnika – podrazumijeva binarnu varijablu koja poprima vrijednost 0 ako je gradonačelnik, koji je obnašao svoju dužnost od 2009. do 2013., ponovno izabran 2013., a u suprotnom poprima vrijednost 1. Konačni rezultati lokalnih izbora 2009. i 2013., dostupni na web stranicama Državnog izbornog povjerenstva (vidi [10]), iskorišteni su kako bi se dobili podatci za ovu varijablu. Lokalni izbori, na kojima se izabiru i gradonačelnici, održavaju se svake četiri godine uz nadzor Državnog izbornog povjerenstva. Kako bi neki političar postao gradonačelnik grada, bio on nezavisan kandidat ili pripadao nekoj političkoj stranci, mora skupiti više od 50 posto glasova birača koji su pristupili glasovanju, inače se otvara novi krug izbora u kojem se natječu prva dva kandidata iz prethodnog kruga, a koji su dobili najviše glasova. Postoje i

slučajevi gdje gradonačelnici i ranije, odnosno, prije novih izbora odstupe s dužnosti zbog specifičnih razloga.

U tablici 3.1. sažete su informacije o svim korištenim varijablama.

VARIJABLA	OZNAKA	IZVOR	FORMULA
Proračunska transparentnost	OLBI	[19]	<i>broj ključnih proračunskih dokumenata na web stranicama grada</i>
Udio visokoobrazovanih	udio_VO	Izračunala autorica pomoću [24] i [26]	$\frac{\text{broj visokoobrazovanih 2011.}}{\text{broj stanovnika 2011}}$
Porezi i prirezi na dohodak po zaposlenom stanovniku	por_prir_po_st	Izračunala autorica pomoću [24] i [17]	$\frac{\text{porez i prirez na dohodak 2014.}}{\text{broj zaposlenih stanovnika 2011.}}$
Reizbor gradonačelnika	prom_grad	Izračunala autorica pomoću [10]	<i>Vrijednost 1 ako je na izborima 2013. na vlast došao novi gradonačelnik, 0 u suprotnom.</i>
Broj stanovnika	br_st	Popis stanovništva iz 2011., ([24])	—

Tablica 3.1 Popis svih varijabli i njihovih oznaka, formula te izvora

Izvor: izrada autorice

3.2. Metodologija istraživanja

Kako bi se odredilo da li i koje od spomenutih varijabli značajnije utječu na transparentnost koristit će se Poissonova regresija. Prije same regresije, proanalizirat će se svaka varijabla,

odnosno napraviti će se njihova deskriptivna statistika. U nastavku slijedi detaljno objašnjenje pojedinih metoda koje će se koristiti.

3.2.1. Poissonova regresija⁵

Poissonova regresija je oblik generaliziranog linearnog modela koji se obično koristi za regresijsku analizu podataka koji imaju cjelobrojne i nenegativne vrijednosti (engl. *count data*), a koje su dobivene prebrojavanjem. Takva je i varijabla proračunske transparentnosti. Njene su vrijednosti, prema definiciji, dobivene prebrojavanjem proračunskih dokumenata koji su objavljeni na web stranicama gradova.

Poissonova regresija je nelinearni regresijski model koji je izveden iz Poissonove distribucije uz uvjet da parametar intenziteta μ ovisi o regresorima, tj. nezavisnim varijablama. Ako je ta zavisnost parametarski točna i uključuje egzogene nezavisne varijable, ali nikakav drugi izvor stohastičke varijacije, onda se takva regresija može primijeniti na odgovarajućim (nezavisnim, egzogenim) varijablama. Uz oznaku Y kao zavisne varijable i $\mathbf{X} = [x_1, \dots, x_k]$ kao vektora nezavisnih varijabli, u primjeni Poissonove regresije, imamo n nezavisnih opažanja gdje je i -to opažanje (y_i, \mathbf{x}_i) . Pri čemu je y_i opažanje zavisne varijable Y , a \mathbf{x}_i opažanje nezavisnog vektora varijabli (regresora) \mathbf{X} koje bi trebalo određivati y_i .

Stoga se regresijski model, baziran na opisanoj distribuciji, dobiva tako da se distribucija y_i uvjetuje k -dimenzionalnim vektorom $\mathbf{x}_i^T = [x_{1i} \dots x_{ki}]$, i vektorom parametara $\boldsymbol{\beta} = (\beta_1, \dots, \beta_k)$, uz neprekidnu funkciju $\mu(\mathbf{x}_i, \boldsymbol{\beta})$ takvu da vrijedi:

$$E[y_i | \mathbf{x}_i] = \mu(\mathbf{x}_i' \boldsymbol{\beta}) \quad (3.1)$$

y_i , uz dani \mathbf{x}_i , ima Poissonovu distribuciju sa gustoćom⁶

⁵ Prema [7].

⁶ U tekstu se $f(y_i | \mathbf{x}_i)$ koristi kao oznaka funkcije gustoće umjesto puno formalnije verzije $f(Y_i = y_i | \mathbf{x}_i)$ kod koje se vidi razlika između slučajne varijable Y i njezine realizacija (opažanja) y .

$$f(y_i|\mathbf{x}_i) = \frac{e^{-\mu_i} \mu_i^{y_i}}{y_i!} \quad (3.2)$$

Kod ovog modela parametar intenziteta (parametar srednje vrijednosti) je definiran kao

$$\mu_i = \exp(\mathbf{x}_i' \boldsymbol{\beta}) \quad (3.3)$$

kako bi se osiguralo $\mu_i > 0$ za svaki i .

Prema svojstvu Poissonove distribucije da je očekivanje jednako varijanci slijedi da mora biti zadovoljena sljedeća jednakost:

$$\text{Var}[y_i|\mathbf{x}_i] = E[y_i|\mathbf{x}_i] \quad (3.4)$$

Ovo svojstvo se u literaturi naziva svojstvom ekvidisperzije.

A prema svojstvima (3.1) i (3.3) i svojstvu da je nepristrani procjenitelj za parametar intenziteta kod Poissonove regresije upravo očekivanje slijedi:

$$E[y_i|\mathbf{x}_i] = \exp(\mathbf{x}_i' \boldsymbol{\beta}) \quad (3.5)$$

Nakon što se jednadžba (3.5) logaritmiraju prirodnim logaritmom dobije se:

$$\ln E[y_i|\mathbf{x}_i] = \mathbf{x}_i' \boldsymbol{\beta} \quad (3.6)$$

Metodom maksimalne vjerodostojnosti traži se nepoznati parametar $\boldsymbol{\beta}$. Funkcija *log*-vjerodostojnosti izgleda ovako:

$$\ln L(\boldsymbol{\beta}) = \sum_{i=1}^n (y_i \mathbf{x}_i' - \exp(\mathbf{x}_i' \boldsymbol{\beta}) - \ln y_i !) \quad (3.7)$$

Njenom derivacijom dobivamo uvjet:

$$\sum_{i=1}^n (y_i - \exp(\mathbf{x}_i' \boldsymbol{\beta})) \mathbf{x}_i = 0 \quad (3.8)$$

pomoću kojeg se onda može izračunati Poissonov procjenitelj maksimalne vjerodostojnosti, u oznaci $\hat{\boldsymbol{\beta}}_p$.

Standardna metoda za računanje $\hat{\boldsymbol{\beta}}_p$ je Newton-Raphsonova iterativna metoda (vidi [7, str. 108]), poznata i kao metoda tangente. Metoda će sigurno konvergirati jer je funkcija *log*-

vjerodostojnosti globalno konkavna. Ova metoda koristit će se prilikom regresijske analize u idućem poglavlju.

3.2.2. Interpretacija parametara Poissonove regresije⁷

Neka je $\beta = (\beta_1, \dots, \beta_k)$ vektor procjenjenih koeficijenata (parametara) Poissonove regresije. Prema jednakosti (3.5) slijedi da promjena j -te varijable x_j vektora \mathbf{X} za jednu jedinicu povećava/smanjuje (ovisno o predznaku β_j) uvjetno očekivanje ($E[Y|\mathbf{X}]$) $\exp(\beta_j)$ puta, uz uvjet da su sve ostale varijable nepromijenjene. Ilustracija ove tvrdnje može se vidjeti kroz sljedeće jednakosti (radi jednostavnosti uzima se da je promjena za jednu jedinicu varijable isto što i promjena za 1):

$$\begin{aligned} \exp(\beta_0 + \beta_1 x_1 + \dots + \beta_j(x_j + 1) + \dots + \beta_k x_k) &= \\ &= \text{svojstvo eksponencijalne funkcije (s. e. f.)} \\ &= \exp(\beta_0) * \exp(\beta_1 x_1) * \dots * \exp(\beta_j(x_j + 1)) * \dots * \exp(\beta_k x_k) \\ &= \text{s. e. f.} \\ &= \exp(\beta_0) * \exp(\beta_1 x_1) * \dots * \exp(\beta_j x_j) * \exp(\beta_j) * \dots * \exp(\beta_k x_k) \end{aligned}$$

Standardna greška procjene regresijskih koeficijenata mjeri koliko precizno model procjenjuje nepoznatu vrijednost koeficijenta. Što je ta greška manja, procjena je točnija. Pretpostavka je da su koeficijenti, odnosno parametri procjene, kod Poissonove regresije normalno distribuirani. To slijedi iz svojstava procjenitelja maksimalne vjerodostojnosti. A, primjerice, *Bootstrap* metodom opisanom u [7, str. 55] može se generirati uzorak procjenitelja koji bi se koristio za izračun standardnih grešaka.

Kako bi se testirala značajnost utjecaja (pozitivnog ili negativnog) određene nezavisne varijable (x_j) na zavisnu (y) u Poissonovom modelu, provodi se Z -test. Kao nul hipoteza uzima se da utjecaj varijable x_j nije značajan na odabranoj razini značajnosti. Drugim

⁷ Prema [7]

riječima, uzima se da je odgovarajući regresijski koeficijent (β_j) jednak 0. Testna statistika Z (Z vrijednost) jest količnik koeficijenta β_j i njegove standardne greške, te, prema definiciji i centralnom graničnom teoremu, asimptotski prati jediničnu normalnu distribuciju. Ukoliko se nul hipoteza odbaci, utvrđuje se da varijabla x_j ima statistički značajan utjecaj na zavisnu varijablu y .

Reziduali mjere odstupanje vrijednosti koje su procijenjene regresijskim modelom od stvarnih vrijednosti zavisne varijable. Obično se koriste kako bi se ispitalo da li je izabrani model dobar ili ga na neki način treba poboljšati. U Poissonovoj regresiji reziduali (engl. *deviance residuals*) se računaju formulom:

$$d_i = \text{sign}(y_i - \hat{\mu}_i) \sqrt{2 \left\{ y_i \ln \left(\frac{y_i}{\hat{\mu}_i} \right) - (y_i - \hat{\mu}_i) \right\}} \quad (3.9)$$

gdje je procijenjeno očekivanje $\hat{\mu}_i$ isto što i uvjetno očekivanje $\mu_i = \mu(x_i' \beta)$ uz $\beta = \hat{\beta}_p$. Također, vrijedi $y \ln y = 0$ ako je $y = 0$.

3.2.3. Testiranje prilagodbe Poissonovog modela podacima ⁸

Postoje različiti načini testiranja koliko je izabrani regresijski model prilagođen stvarnim podacima, odnosno koliko dobro taj model procjenjuje vrijednosti zavisne varijable.

Uobičajena mjera koja se koristi kod testiranja Poissonovog regresijskog modela (ili, općenito, generaliziranog linearnog modela) jest devijanca. Devijanca uspoređuje izabrani regresijski model sa saturiranim modelom. Saturirani (zasićeni) model je onaj za kojeg se postiže najveći mogući procjenitelj maksimalne vjerodostojnosti definiran u skladu sa (3.7). U idućem poglavlju, uzima se da je saturirani model onaj kod kojeg su procijenjene (prediktivne) vrijednosti jednake opaženim vrijednostima, tj. stvarnim podacima zavisne varijable (vidi [5]). Sada se može definirati devijanca D kao:

⁸ Prema [5] i [7]

$$D = 2[l(\hat{\mu}) - l(\hat{\beta})] \quad (3.10)$$

Gdje je $l(\hat{\mu})$ maksimizirana log vjerodostojnosti za saturirani model, a $l(\hat{\beta})$ maksimizirana log vjerodostojnost za (izabrani) regresijski model. Za Poissonovu regresiju vrijedi da je devijanca oblika:

$$D = 2 \sum d_i \quad (3.11)$$

Da bi se zaključilo da je izabrani model dobro opisuje stvarne podatke, prema [5] treba vidjeti da li (asimptotski) vrijedi:

$$D \sim \chi_{K-p}^2 \quad (3.12)$$

Gdje je K i p broj parametara u saturiranom, odnosno izabranom/pretpostavljenom modelu. Dakle, (3.12) je nul hipoteza za testiranje prilagođenosti Poissonovog modela.

Akaike informacijski kriterij (engl. *Akaike Information Criterion*), skraćeno *AIC*, jest mjera pomoću koje možemo uspoređivati 'prilagođenost' različitih modela, dobivenih istom regresijskom metodom. Drugim riječima, od nekoliko različitih modela možemo izabrati onaj koji najbolje odgovara stvarnim podacima. Formula po kojoj se računa *AIC* vrijednost jest:

$$AIC = -2l + 2k \quad (3.13)$$

Pri čemu je l funkcija *log* vjerodostojnosti, a k broj procijenjenih koeficijenata/parametara (uključujući i slobodni član).

Najbolji model je onaj koji ima najmanju *AIC* vrijednost. Iz formule (3.13) vidi se da je *AIC* vrijednost veća što je broj procijenjenih parametara/koeficijenata veći.

3.2.4. Test disperzije

U Poissonovom modelu, prema pretpostavci (3.4), uvjetno očekivanje zavisne varijable $E[Y|\mathbf{X}] = \mu$ jednako je uvjetnoj varijanci $Var[Y|\mathbf{X}]$, a za provjeru njene valjanosti koristi se test disperzije (vidi [7, str. 200]). Ako je narušena navedena pretpostavka onda postoji konstanta c takva da vrijedi:

$$Var[Y|\mathbf{X}] = \mu + cf(\mu) \quad (3.13)$$


gdje je f proizvoljna monotona funkcija. U skladu s tim, nul hipoteza glasi $c = 0$ nasuprot alternative $c \neq 0$.

4. EMPIRIJSKA ANALIZA

U ovom dijelu rada prikazat će se deskriptivna statistika svake od varijabli, te će se ispitati njihova koreliranost. Zatim slijedi Poissonova regresija, testiranje prilagodbe modela uz diskusiju dobivenih rezultata.

4.1. Deskriptivna statistika

Prema dobivenim podacima [19] zna se kolika je proračunska transparentnost pojedinog grada, odnosno, prema definiciji spomenutoj u ranijim poglavljima, koliko je pojedini grad objavio ključnih proračunskih dokumenata tijekom 2015./2016. Na temelju tih podataka konstruirana je zavisna varijabla *OLBI*. U skladu s definicijom, ova varijabla može poprimiti vrijednosti između 0 i 5 ovisno o tome koliko je ključnih proračunskih dokumenata objavio pojedini grad. Graf apsolutnih frekvencija *OLBI* varijable vidi se na slici 4.1.



Slika 4.1 Graf apsolutnih frekvencija varijable *OLBI*

Izvor: izrada autorice

Najviše gradova, njih 35, objavilo je četiri proračunska dokumenta, a najmanje gradova, njih 9, nije objavilo niti jedan dokument. Prosječna transparentnost svih hrvatskih gradova iznosi 3,04 uz varijancu od 2,39.

Gradovi čija je transparentnost jednaka jedan uglavnom su objavljivali samo izglasani proračun za 2016. Gradovi koji su objavljivali proračun za građane za 2016. su uglavnom oni gradovi čija je transparentnost jednaka 5. Prema količini objavljenih dokumenata po gradovima, zastupljenost ključnih proračunskih dokumenata u sveukupnom broju gradova izgleda ovako:

Proračunski dokument	Broj gradova koji su objavili dokument
Godišnje izvršenje proračuna za 2014.	98
Polugodišnje izvršenje proračuna za 2015.	88
Prijedlog proračuna za 2016.	67
Izglasani proračun za 2016.	106
Proračun za građane za 2016.	27

Tablica 4.1 Zastupljenost ključnih proračunskih dokumenata

Izvor: izrada autorice

U tablici 1 u Dodatku ovog rada nalaze se svi gradovi, njihov indeks transparentnosti uz prikaz objavljenih proračunskih dokumenata.

Uz zavisnu *OLBI* varijablu, tu su i već spomenute nezavisne varijable i njihove oznake koje će se koristiti u daljnjem tekstu:

Oznaka	Nezavisna varijabla
<i>udio_VO</i>	Udio visokoobrazovanih osoba
<i>por_prir_po_st</i>	Porez i prirez na dohodak po zaposlenom stanovniku
<i>br_st</i>	Broj stanovnika
<i>prom_grad</i>	Reizbor gradonačelnika

Tablica 4.2 Oznake nezavisnih varijabli

Izvor: izrada autorice

U tablici 4.3 mogu se vidjeti temeljne karakteristike svake nezavisne varijable:

nezavisna varijabla	veličina uzorka	Sr. vrijednost	St. devijacija	Minimum	Maksimum
<i>por_prir_po_st</i>	127	4.270,61	1.364,67	1.531,69	8.336,25
<i>promjena_grad</i>	127	0,43	0,50	0	1
<i>br_st_2011</i>	127	17.622,24	23.818,72	1.526,00	178.102,00
<i>udio_VO</i>	127	0,11	0,04	0,04	0,24

Tablica 4.3 Deskriptivna statistika nezavisnih varijabli

Izvor: izrada autorice

Tablica 2 u Dodatku ovog rada nudi detaljni prikaz vrijednosti nezavisnih i zavisne varijable za svaki grad.


Kako bi se pokušala predočiti moguća veza između svake od nezavisnih varijabli i varijable *OLBI*, u tablici 4.4. prikazane su izračunate srednje vrijednosti pojedine nezavisne varijable za svaku od mogućih razina varijable *OLBI*.

Razina OLBI varijable	Srednja vrijednost			
	<i>por_prir_po_st</i>	<i>promjena_grad</i>	<i>br_st_2011</i>	<i>udio_VO</i>
0	3.425,86	0,3333	11.750,67	0,0859
1	3.767,99	0,2105	9.836,89	0,0853
2	3.782,03	0,6154	8.507,85	0,1060
3	3.927,14	0,5185	12.788,96	0,1079
4	4.609,39	0,5429	16.280,43	0,1159
5	5.142,31	0,2917	38.318,71	0,1526

Tablica 4.4 Srednje vrijednosti nezavisnih varijabli po razinama *OLBI* varijable


Izvor: izrada autorice

Iste vrijednosti označene su crvenim točkama i povezane plavim linijama na sljedećim slikama:




Slika 4.2 Prikaz veze varijabli *OLBI* i *udio_VO*

Izvor: izrada autorice




Slika 4.3 Prikaz veze varijabli *OLBI* i *por_prir_po_st*

Izvor: izrada autorice



Slika 4.4 Prikaz veze varijabli *OLBI* i *br_st*

Izvor: izrada autorice



Slika 4.5 Prikaz veze varijabli *OLBI* i *prom_grad*

Izvor: izrada autorice

Pomoću grafova na slici 4.5 i tablice 4.4 u kojima se približno vizualizira veza proračunske transparentnosti i ostalih varijabli možemo uočiti da bi možda mogla postojati pozitivna veza varijabli *OLBI* i *por_prir_po_st*, te *OLBI* i *udio_VO*, ali ne i kolika bi bila statistička značajnost te veze.

Prije nego se započne računanje izabranom metodom regresije, treba se provjeriti jesu li i u kojoj mjeri nezavisne varijable međusobno korelirane. Ukoliko su neke varijable

međusobno visoko korelirane, treba se vidjeti ako će se i koja od njih izbaciti iz modela. Tablica 4.5. sadrži sve moguće koeficijente korelacije između svih varijabli (i nezavisnih i zavisne *OLBI* varijable).

Pearsonov koeficijent korelacije ⁹					
	<i>udio_VO</i>	<i>por_prir_po_st</i>	<i>br_st</i>	<i>prom_grad</i>	<i>OLBI</i>
<i>udio_VO</i>	1	-	-	-	-
<i>por_prir_po_st</i>	0,63	1	-	-	-
<i>br_st</i>	0,52	0,33	1	-	-
<i>prom_grad</i>	-0,06	-0,06	0,06	1	-
<i>OLBI</i>	0,49	0,38	0,33	0,06	1

Tablica 4.5 Tablica koreliranosti

Izvor: izrada autorice

OLBI i *udio_VO* imaju najveći koeficijent korelacije 0,49 što ukazuje na to da će ta varijabla vjerojatno imati najviše utjecaja na *OLBI*. Druga po koreliranosti je varijabla *por_prir_po_st* dok varijabla *prom_grad* nije korelirana ni sa jednom od varijabli. Također, može se uočiti da su sljedeći parovi varijabli poprilično korelirani: *por_prir_po_st* i *udio_VO* sa 0,63 , te *udio_VO* i *br_st* sa 0,52. Stoga bi se neke od varijabli trebale izbaciti iz modela, odnosno konstruirati više modela koji će se međusobno razlikovati u minimalno jednoj varijabli. U svrhu analize napraviti će se više različitih modela.

⁹ Koeficijenti izračunati prema formuli $\frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}$ gdje su x_i i y_i opažene vrijednosti proizvoljnih varijabli X i Y , a \bar{x} i \bar{y} srednje vrijednosti svih opaženih vrijednosti. (vidi [16])

4.2. Poissonova regresija

U programu R (verzija 3.4.0), koji je pogodan za statističku analizu i računanje, prema ranije definiranoj teoriji i metodama računanja, provodi se Poissonova regresija¹⁰. Kada se govori o statističkoj značajnosti misli se na razinu značajnosti od 5 posto, odnosno 95 postotnu pouzdanost procjene koeficijenata.

Prvo se konstruira model M1 koji uključuje sve spomenute nezavisne varijable:

$$E[OLBI] = \exp(\beta_0 + \beta_1 udio_VO + \beta_2 por_prir_po_st + \beta_3 br_st + \beta_4 prom_grad1)$$

model M1

varijabla	Koeficijent β_i	$\exp(\beta_i)$	Standardna greška	Z vrijednost	p vrijednost
<i>slobodni član</i>	0,309	1,362	0,197	1,565	0,117
<i>udio_VO</i>	0,046	1,048	0,018	2,623	0,009
<i>por_prir_po_st</i>	0,000	1,000	0,000	0,939	0,347
<i>br_st</i>	0,000	1,000	0,000	0,359	0,719
<i>prom_grad1</i>	0,092	1,097	0,104	0,886	0,375

Tablica 4.6 Rezultati regresije modela M1

Izvor: izrada autorice

Nul devijanca: 130,25 (uz 126 stupnjeva slobode)

Rezidualna devijanca: 105,40 (uz 122 stupnja slobode)

AIC: 465,99

¹⁰ Koristi se funkcija `glm()` pri čemu je "family=poisson".

Provedenom regresijom s navedenim modelom u R-u dobije se da jedino varijabla *udio_VO* statistički značajno utječe na *OLBI*, odnosno da udio visokoobrazovanih ima najviše utjecaja na proračunsku transparentnost gradova. Njezin koeficijent regresije β_1 iznosi 0,046, odnosno njena eksponencijalna vrijednost 1,048. To bi značilo da se povećanjem udjela visokoobrazovanih osoba za 1 posto (uz sve ostale varijable nepromijenjene) transparentnost *OLBI* multiplikativno poveća za 1,048, odnosno za 4,8 posto. No, ako bi se, primjerice, udio visokoobrazovanih osoba u nekom gradu povećao za 10 posto, proračunska transparentnost mogla bi se povećati za gotovo 60 posto. Standardna greška za procijenjeni koeficijent β_1 jest 0,018.

Treba istaknuti da su koeficijenti uz sve ostale nezavisne varijable pozitivni što ukazuje na njihov pozitivan utjecaj na zavisnu varijablu *OLBI*, ali obzirom na prevelike *p* vrijednosti, zaključuje se da nemaju statistički značajnijeg utjecaja na transparentnost. Kada se pojedinačno gledaju, njihove standardne greške jesu male, ali kada se usporede s vrijednošću odgovarajućeg koeficijenta vide se prevelika odstupanja. Što se tiče binomne varijable *prom_grad*, u tablici 4.6 vidi se da samo vrijednost 1, odnosno promjena gradonačelnika na izborima, pozitivno utječe na transparentnost. Može se uočiti da su kod te varijable i slobodnog člana koeficijenti ipak malo veći, ali i dalje nedovoljno statistički značajni da ih se uzme u obzir kao varijable koje određuju proračunsku transparentnost. Rezidualna devijanca modela M1 jest manja od nul devijance, što upućuje na to da će (prediktivno) bolji model biti onaj koji sadrži sve varijable u odnosu na onaj koji sadrži samo slobodni član. *AIC* vrijednost iznosi 465,99, ali malo kasnije će biti od koristi kada se ovaj model bude uspoređivalo s drugim modelima.

Dakle, Poissonovom regresijom dobiveni su rezultati koji su u skladu s prije spomenutom tablicom korelacija. Za sve nezavisne neprekidne varijable postoji pozitivna veza sa zavisnom, *OLBI* varijablom, ali je veza značajna samo za *udio_VO*. Utjecaj varijable *udio_VO* je i u skladu s rezultatima Serrano-Cince i dr. [25] te Gandie i Archidona [11]. Serrano-Cinca i dr. [25] navode i da će lokalne vlasti čiji su građani jako socijalno i politički savjesni javno objaviti financijske izvještaje kao posljedicu pritiska tih građana. A kao što se pretpostavlja u uvodu ovoga rada, takvi građani, koji su upućeniji u politički život i probleme, koji su skloniji dubljim analizama, su upravo visokoobrazovani. S druge

strane, ukoliko je u pojedinom gradu veći udio visokoobrazovanih osoba možda je veća vjerojatnost da će i u gradskoj upravi biti više takvih osoba, čiji zaposlenici će onda znati sastaviti i na web stranicama na vrijeme objaviti ključne proračunske dokumente.

Promatramo zatim model M2:

$$E[OLBI] = \exp(\beta_0 + \beta_1 udio_VO + \beta_2 br_st + \beta_3 prom_grad1)$$

model M2

U ovom modelu izbačena je varijabla *por_prir_po_st*, jer je upravo kod te varijable uočena povećana korelacija s ostalim nezavisnim varijablama (vidi tablicu 4.5) osim s varijablom *prom_grad* koja nije visokokorelirana s nijednom nezavisnom varijablom, ali ni sa samom zavisnom, *OLBI* varijablom, kod koje je koeficijent korelacije jako nizak, i iznosi 0,05. Rezultati provedene regresije nad modelom M2 vidljivi su u tablici 4.7.

varijabla	Koeficijent β_i	$\exp(\beta_i)$	Standardna greška	Z vrijednost	p vrijednost
<i>slobodni član</i>	0,393	1,481	0,175	2,242	0,025
<i>udio_VO</i>	0,056	1,058	0,014	3,950	0,001
<i>br_st</i>	0,000	1,000	0,000	0,338	0,736
<i>prom_grad1</i>	0,087	1,091	0,104	0,834	0,405

Tablica 4.7 Rezultati regresije modela M2

Izvor: izrada autorice

Nul devijanca: 130,25 (uz 126 stupnjeva slobode)

Rezidualna devijanca: 106,27 (uz 123 stupnja slobode)

AIC: 464,87

Kao i u modelu M1, *udio_VO* ima statistički značajan pozitivan utjecaj na *OLBI* varijablu, uz sada još manju p vrijednost, odnosno veću statističku značajnost. No, u modelu M2 i slobodni član dolazi do izražaja uz pet postotnu značajnost. Standardne greške varijabli

udio_VO i slobodnog člana kod ovog modela su se smanjile, dok su se za ostale varijable neznatno povećale ili ostale iste. *AIC* vrijednost smanjena je za 1,12. Razlika nije velika, pa se u nastavku konstruira novi model M3 kod kojeg će se izbaciti varijabla *br_st*, zbog koreliranosti s varijablom *udio_VO*, te varijabla *prom_grad* zbog slabe koreliranosti sa *OLBI* varijablom.

$$E[OLBI] = \exp(\beta_0 + \beta_1 \text{udio_VO})$$

model M3

varijabla	Koeficijent β_i	$\exp(\beta_i)$	Standardna greška	Z vrijednost	p vrijednost
<i>slobodni član</i>	0,422	1,525	0,155	2,718	0,007
<i>udio_VO</i>	0,058	1,060	0,012	4,905	0,000

Tablica 4.8 Rezultati regresije modela M3

Izvor: izrada autorice

Nul devijanca: 130,25 (uz 126 stupnjeva slobode)

Rezidualna devijanca: 107,19 (uz 125 stupnja slobode)

AIC: 461,78

Kao i kod modela M2, model M3 ima veće koeficijente regresije i manje standardne greške, jednopostotno povećanje udjela visokoobrazovanih u ovom modelu povećava transparentnost za 6 posto, dok je u modelu M1 povećanje iznosilo 4 posto, uz sve ostale varijable nepromijenjene. Dakle, statistička značajnost se povećala, ali utjecaj udjela visokoobrazovanih na transparentnost nije se znatno promijenio. *AIC* je sada još manji (za 3,09) što znači da je model M3 najbolji u prediktivnom smislu.

Sljedeći po redu jest model M4 u kojem se izbacuje varijabla *udio_VO*, a dodaju se sve ostale nezavisne varijable:

$$E[OLBI] = \exp(\beta_0 + \beta_1 \text{por_prir_po_st} + \beta_2 \text{br_st} + \beta_3 \text{prom_grad1})$$

model M1

varijabla	Koeficijent β_i	exp (β_i)	Standardna greška	Z vrijednost	p vrijednost
<i>slobodni član</i>	0,499	1,647	0,183	2,724	0,006
<i>por_prir_po_st</i>	0,000	1,000	0,000	3,052	0,002
<i>br_st</i>	0,000	1,000	0,000	1,851	0,064
<i>prom_grad1</i>	0,071	1,074	0,103	0,688	0,491

Tablica 4.9 Rezultati regresije modela M4

Izvor: izrada autorice

Nul devijanca: 130,25 (uz 126 stupnjeva slobode)

Rezidualna devijanca: 112,24 (uz 123 stupnja slobode)

AIC: 470,84

Kao što se moglo očekivati do izražaja je došla varijabla *por_prir_po_st*, koja je ujedno i druga po koreliranosti s *OLBI* varijablom uz koeficijent koreliranosti 0,38, a odmah iza *udio_VO* (vidi tablicu 4.5). Koeficijent regresije varijable *por_prir_po_st* jest 0,00012¹¹ uz standardnu grešku manju nego u modelu M1, odnosno povećanje prireza od 1 kune po stanovniku (uz sve ostale varijable nepromijenjene) značilo bi da će se transparentnost povećati za 0,012 posto. U stvarnosti, porez bi se mogao povećati za, primjerice, 500 kuna po (zaposlenom) stanovniku, što bi onda značilo, uz sve ostale varijable nepromijenjene, da će se transparentnost povećati za 6 posto, što je zapravo gotovo beznačajno. p vrijednost za koeficijent varijable *br_st* se u ovom modelu znatno smanjio, ali nedovoljno da bi se utvrdio utjecaj broja stanovnika na transparentnost. Rezultati za varijablu *prom_grad* u modelu M4 su približno jednaki kao u prethodnim modelima te i dalje vrijedi da promjena gradonačelnika na izborima pozitivno i "nedovoljno" utječe na transparentnost. AIC

¹¹ U tablici 4.9 odgovarajuća vrijednost zaokružena je na tri decimale.

modela M3 se u usporedbi s prethodnim modelom povećao, što je bilo za očekivati, a veći je za 4,85 od *AIC* vrijednosti modela M1.

Svi modeli i njihove *AIC* vrijednosti mogu se još jednom usporediti u tablici 4.10.

MODEL	AIC
M1	465,99
M2	464,87
M3	461,78
M4	470,84

Tablica 4.10 Usporedba regresijskih modela prema *AIC* kriteriju

Izvor: izrada autorice

Razlike u *AIC* vrijednostima nisu velike. Najmanji *AIC* ima upravo model sa samo jednom varijablom (*udio_VO*). No, ne mora značiti da je taj model najbolji, jer razlog manje vrijednosti može biti i taj što je *AIC* vrijednost, prema spomenutom u trećem poglavlju, manja što je broj varijabli u modelu manji. Poveća koreliranost među pojedinim nezavisnim varijablama, isto je jedan od uzroka što se *AIC* vrijednosti ne razlikuju. Naime, izbacivanje varijabli koje su korelirane s drugim varijablama u modelu, najvjerojatnije neće uzrokovati promjene u modelu, tj. neće ga poboljšati ili pogoršati. Isto vrijedi i za dodavanje koreliranih varijabli.

4.3. Testiranje modela

Kako bi se provjerilo jesu li navedeni modeli dobro prilagođeni stvarnim podacima, prema definiranom u trećem poglavlju, treba testirati nul hipotezu da (rezidualna) devijanica asimptotski slijedi hi-kvadrat razdiobu. Testiranje se provodi na razini značajnosti od 5 posto.

Izračunom u R-u dobiju se podatci navedeni u tablici 4.11:


model	rezidualna devijanca	p vrijednost ¹²
M1	105,40	0,86
M2	106,27	0,86
M3	107,19	0,87
M4	112,24	0,74

Tablica 4.11 Rezultati testa prilagodbe regresijskih modela

Izvor: izrada autorice


p vrijednost nijednog modela nije manja od 0,05. Drugim riječima na razini značajnosti do 5 posto ne odbacujemo nul hipotezu, tj. svi modeli su dobro prilagođeni.

Na slici 4.6 mogu se vidjeti grafovi reziduala, definiranih u prethodnom poglavlju.



¹² U R-u se koristi naredba:

1 - pchisq(rezidualna devijanca, broj stupnjeva slobode u modelu)



Slika 4.6 Reziduali regresijskih modela

Izvor: izrada autorice

Provjera prilagodbe regresijskih modela stvarnim podacima navodi na zaključak da bi svi modeli mogli biti dobro 'prilagođeni', što potvrđuje da bi procjene koeficijenata i procjene očekivane vrijednosti zavisne varijable dobivene pomoću Poissonove regresije mogle imati smisla.

4.4 Test disperzije

Test disperzije proveden u R-u¹³ upućuje na to da je $c < 0$ kod svih modela, odnosno da je narušena pretpostavka ekvidisperzije (3.4). Prema tome, Poissonova regresija nije najbolji izbor za modeliranje povezanosti korištenih varijabli.

¹³ Koristi se naredba: `dispersiontest(model, alternative="two.sided")`.

5. ZAKLJUČAK

Proračuni lokalnih jedinica bitan su izvor informacija o njihovom financijskom stanju i mogu poslužiti kao mjera nadzora odluka lokalnih vlasti. Koristeći Poissonovu regresiju u radu se pokušalo ispitati mogu li određene varijable utjecati na transparentnost.

Krenulo se od pretpostavke da sve izabrane varijable (porezi i prirez na dohodak po zaposlenom stanovniku iz 2014., broj stanovnika iz 2011., udio visokoobrazovanih iz 2011. i promjena gradonačelnika iz 2013. u odnosu na prethodne izbore) pozitivno utječu na transparentnost. Na osnovu toga definirale su se odgovarajuće hipoteze. Varijabla proračunske transparentnosti preuzeta je iz Ott i dr. [19]. Ispitivanje se radilo na uzorku od 127 gradova, bez grada Zagreba.

Od svih izabranih varijabli pokazalo se da samo udio visokoobrazovanih osoba ima statistički značajan i pozitivan utjecaj na proračunsku transparentnost hrvatskih gradova. Razlog utjecaja visokoobrazovanosti na transparentnost može ležati u tome što obrazovaniji ljudi kritičnije pristupaju pojedinoj temi, više analiziraju i preispituju životne situacije. Pod uvjetom da ih zanima lokalna politika, od gradskih vlasti traže veću transparentnost i više informacija o tome kako se u gradu raspolaže financijskim sredstvima.

U stvarnosti se jako mali broj građana (ne samo visokoobrazovanih) bavi gradskim proračunskim dokumentima, bilo u svrhu informiranja ili pak dubljeg analiziranja. Stoga, razlog možda leži u visokoj obrazovanosti unutar gradskih tijela koja sastavljaju i objavljuju proračunske dokumente. Jer, ukoliko je u gradu veći udio visokoobrazovanih osoba možda je veća vjerojatnost da će i u gradskoj upravi biti više takvih osoba, čiji zaposlenici će onda znati sastaviti i na web stranicama na vrijeme objaviti ključne proračunske dokumente. No, možda postoje i neki drugi razlozi koji nisu odmah uočljivi i koje bi u budućnosti trebalo istražiti.

Ostale varijable su pokazale gotovo zanemariv pozitivan utjecaj na transparentnost.

Iako su se korišteni modeli regresije pokazali valjanima, rezultate regresije treba uzeti uz dozu opreznosti pošto je jedna od ključnih teorijskih pretpostavki (ekvidisperzija) Poissonovog modela narušena. Stoga se, za daljnje analize utjecaja na proračunsku transparentnost preporuča korištenje i drugih pogodnih regresijskih metoda te novih, dodatnih, nezavisnih varijabli

Jedan od nedostataka ovog rada su i podatci koji su uglavnom zastarjeli. Za sve nezavisne varijable dostupni su uglavnom bili podatci iz 2011., 2013. ili pak 2014., dok je samo varijabla proračunske transparentnosti trenutno aktualna. Također, duža vremenska serija podataka dala bi vjerodostojnije rezultate i možda potvrdila neke trendove.

Pored nedostataka ovog rada treba spomenuti i slabu zainteresiranost građana za gradske proračune. Jer da bi ovakva istraživanja imala još više smisla, oni bi se trebali više interesirati za gradska proračune i u okviru ponuđenih mogućnosti aktivnije sudjelovati u kreiranju politike svojih gradova.

Ali, osim ključnih proračunskih dokumenata, gradska tijela trebala bi davati još konkretnijih i transparentnijih informacija kako bi građani mogli dobiti širu sliku o funkcioniranju svojih gradova te kako bi se moglo stvoriti veće povjerenje između njih.

6. LITERATURA

- [1] A.F. Alesina, R. Perotti, *Budget Deficits and Budget Institutions*, dostupno na <http://www.nber.org/chapters/c8021.pdf> (lipanj 2017.)
- [2] A.F. Alesina, R. Perotti, *Fiscal Discipline and the Budget Process*, dostupno na http://www.rperotti.com/doc/PAPER_AER_1996_Fiscal_discipline_and_the_budget_process.pdf (lipanj 2017.)
- [3] J. Alt, D.Dreyer Lassen, *Transparency, Political Polarization, and Political Budget Cycles in OECD Countries*, dostupno na https://www.researchgate.net/publication/237455752_Transparency_Political_Polarization_and_Political_Budget_Cycles_in_OECD_Countries (lipanj 2017.)
- [4] J.E. Alt, R.C. Lowry, *Transparency and Accountability: Empirical Results for US States*, dostupno na https://dash.harvard.edu/bitstream/handle/1/9468172/Alt_Transparency.pdf?sequence=1 (lipanj 2017.)
- [5] J. Bartlett, *Deviance goodness of fit test for Poisson regression*, dostupno na <http://thestatsgeek.com/2014/04/26/deviance-goodness-of-fit-test-for-poisson-regression/> (lipanj 2017.)
- [6] A. Bellver, D. Kaufmann, *Transparenting Transparency*, dostupno na: https://siteresources.worldbank.org/INTWBIGOVANTCOR/Resources/Transparenting_Transparency171005.pdf (lipanj 2017.)
- [7] A.C. Cameron, P.K. Trivedi, *Regression Analysis of Count data*, Cambridge University press, New York ,2013.
- [8] The Comprehensive R Archive Network, dostupno na <https://cran.r-project.org/> (lipanj 2017.)
- [9] R. Debreceeny, G.L. Gray, A.Rahman, *The determinants of Internet financial reporting*, dostupno na <http://www.sciencedirect.com/science/article/pii/S0278425402000674> (lipanj 2017)

- [10] Državno izborno povjerenstvo Republike Hrvatske, dostupno na <http://www.izbori.hr/ws/index.html?documentId=DF2CA3FEF99BA5CBC1257C5C004BF6B4> (lipanj 2017.)
- [11] J.L. Gandia, M.C. Archidona, *Determinants of web site information by Spanish city councils*, dostupno na <http://www.emeraldinsight.com/doi/pdfplus/10.1108/14684520810865976> (lipanj 2017.)
- [12] M.D. Guillamón, F. Bastida, B. Benito, *The Determinants of Local Government's Financial Transparency*, dostupno na <http://www.tandfonline.com/doi/full/10.1080/03003930.2011.588704> (lipanj 2017.)
- [13] R. Islam, *Do More Transparent Governments Govern Better?*, dostupno na http://documents.worldbank.org/curated/en/568401468741328131/109509322_20041117183019/additional/multi0page.pdf (lipanj 2017.)
- [14] L. Ma, J. Wu, *What Drives Fiscal Transparency? Evidence from Provincial Governments in China*, dostupno na https://spaa.newark.rutgers.edu/sites/default/files/files/Transparency_Research_Conference/Papers/Ma_Liang.pdf (lipanj 2017.)
- [15] Model Adequacy - Deviance, dostupno na <http://people.stat.sfu.ca/~raltman/stat402/402L11.pdf> (lipanj 2017.)
- [16] Opisna statistika, dostupno na https://web.math.pmf.unizg.hr/nastava/stat/files/chap1_novo.pdf (lipanj 2017.)
- [17] Ostvarenje proračuna JLP(R)S za period 2010. - 2014., dostupno na <http://www.mfin.hr/hr/ostvarenje-proracuna-jlprs-za-period-2010-2014> (lipanj 2017.)
- [18] K. Ott, M. Bronić, *Ostvarenje proračuna općina, gradova i županija u 2014.*, dostupno na <http://www.ijf.hr/upload/files/file/newsletter/98.pdf> (lipanj 2017.)
- [19] K. Ott, M. Bronić, M. Petrušić, B. Stanić, *Proračunska transparentnost županija, gradova i općina: studeni 2015. – ožujak 2016.*, dostupno na <http://www.ijf.hr/upload/files/107.pdf> (lipanj 2017.)

- [20] Partnerstvo za otvorenu vlast, dostupno na <https://udruga.gov.hr/istaknute-teme/partnerstvo-za-otvorenu-vlast-271/271> (lipanj 2017.)
- [21] C.C. Pérez, A.M. López Hernández, M.P. Rodríguez Bolívar, *Citizens' access to on-line governmental financial information: Practices in the European Union countries*, dostupno na <http://www.sciencedirect.com/science/article/pii/S0740624X05000183#> (lipanj 2017.)
- [22] Poisson Regression Model, dostupno na <https://onlinecourses.science.psu.edu/stat504/node/168> (lipanj 2017.)
- [23] Popis stanovništva, kućanstava i stanova 2011. godine, dostupno na <http://www.dzs.hr/Hrv/censuses/census2011/results/censustabsxls.htm> (lipanj 2017.)
- [24] Procjene stanovništva Republike Hrvatske u 2015., dostupno na http://www.dzs.hr/Hrv_Eng/publication/2016/07-01-04_01_2016.htm (lipanj 2017.)
- [25] C. Serrano-Cinca, M. Rueda-Tomás, P. Portillo-Tarragona, *Factor influencing e-disclosure in Local Public Administrations*, dostupno na <http://www.dteconz.unizar.es/DT2008-03.pdf> (lipanj 2017.)
- [26] Stanovništvo staro 15 i više godina prema najvišoj završenoj školi, obrazovnim područjima i spolu, Popis 2011., dostupno na http://www.dzs.hr/Hrv/censuses/census2011/results/htm/h01_01_36/H01_01_36.html#02 (lipanj 2017.)
- [27] A.K. Styles, M. Tennyson, *The Accessibility of Financial Reporting of U.S. Municipalities on the Internet*, dostupno na http://pracademics.com/attachments/article/703/Art%203%20Styles_Tennyson.pdf (lipanj 2017.)
- [28] Zakon o izmjeni Zakona o financiranju jedinica lokalne i područne (regionalne) samouprave, dostupno na http://narodne-novine.nn.hr/clanci/sluzbeni/2015_09_100_1939.html (lipanj 2017.)

Dodatak

Tablica 1. Ključni proračunski dokumenti objavljeni na web stranicama hrvatskih gradova

GRAD	Godišnje izvršenje proračuna za 2014.	Polugodišnje izvršenje proračuna za 2015.	Prijedlog proračuna za 2016.	Izglasani proračun za 2016.	Proračun za građane za 2016.	OLBI 2016
Bakar	1	1	0	1	1	4
Beli Manastir	0	0	0	0	0	0
Belišće	0	0	0	1	0	1
Benkovac	0	1	0	1	0	2
Biograd na Moru	1	0	0	1	0	2
Bjelovar	1	1	1	1	1	5
Buje	1	1	0	1	1	4
Buzet	1	1	1	1	1	5
Cres	1	1	1	1	1	5
Crikvenica	1	1	1	1	1	5
Čabar	1	0	0	0	0	1
Čakovec	1	1	1	1	0	4
Čazma	0	0	0	1	0	1
Daruvar	1	1	0	1	0	3
Delnice	1	1	1	1	0	4
Donja Stubica	1	1	0	1	0	3
Donji Miholjac	1	1	0	1	0	3
Drniš	1	1	1	1	0	4
Dubrovnik	1	1	1	1	0	4
Duga Resa	1	1	1	1	1	5
Dugo Selo	1	1	0	1	0	3
Đakovo	0	0	0	1	0	1
Đurđevac	1	1	1	0	0	3
Garešnica	1	1	1	1	0	4
Glina	1	1	1	1	0	4
Gospić	0	0	0	1	0	1
Grubišno Polje	1	0	0	1	0	2
Hrvatska Kostajnica	1	1	1	1	0	4
Hvar	1	1	1	1	0	4
Ilok	0	0	0	0	0	0
Imotski	0	0	0	0	0	0
Ivanec	1	1	1	1	1	5
Ivanić-Grad	1	1	1	1	0	4
Jastrebarsko	1	1	1	1	0	4
Karlovac	1	1	1	1	1	5
Kastav	1	1	1	1	1	5
Kaštela	1	1	1	1	0	4
Klanjec	1	1	1	1	0	4
Knin	0	0	0	1	0	1
Komiža	1	1	0	1	0	3
Koprivnica	1	1	1	1	1	5
Korčula	1	1	1	1	0	4
Kraljevica	1	0	1	0	0	2
Krapina	1	1	0	1	0	3
Križevci	1	1	0	1	1	4
Krk	1	1	1	1	0	4
Kutina	1	0	1	1	0	3
Kutjevo	0	0	0	0	0	0

GRAD	Godišnje izvršenje proračuna za 2014.	Polugodišnje izvršenje proračuna za 2015.	Prijedlog proračuna za 2016.	Izglasani proračun za 2016.	Proračun za građane za 2016.	OLBI 2016
Labin	1	1	1	1	1	5
Lepoglava	1	1	1	1	0	4
Lipik	1	1	1	1	0	4
Ludbreg	1	0	1	0	0	2
Makarska	1	1	1	1	0	4
Mali Lošinj	1	1	1	1	1	5
Metković	1	1	0	1	0	3
Mursko Središće	0	1	0	1	0	2
Našice	0	1	0	0	0	1
Nin	0	0	0	0	0	0
Nova Gradiška	1	0	0	1	0	2
Novalja	1	0	0	1	0	2
Novi Marof	1	0	0	1	0	2
Novi Vinodolski	1	1	0	1	0	3
Novigrad	1	1	1	1	0	4
Novska	1	1	0	1	0	3
Obrovac	0	0	0	1	0	1
Ogulin	1	1	1	1	0	4
Omiš	1	1	1	0	0	3
Opatija	1	1	1	1	1	5
Opuzen	1	1	0	1	0	3
Orahovica	1	1	1	1	0	4
Oroslavje	0	0	0	1	0	1
Osijek	1	1	1	1	1	5
Otočac	1	0	0	1	0	2
Otok (Vinkovci)	0	1	0	0	0	1
Ozalj	1	1	1	1	1	5
Pag	1	0	0	0	0	1
Pakrac	1	1	0	1	0	3
Pazin	1	1	1	1	1	5
Petrinja	1	1	0	1	0	3
Pleternica	0	0	0	0	0	0
Ploče	1	0	0	1	0	2
Popovača	1	0	0	0	0	1
Poreč	1	1	1	1	1	5
Požega	1	1	1	0	0	3
Pregrada	1	1	1	1	0	4
Prelog	1	0	1	1	0	3
Pula	1	1	1	1	1	5
Rab	1	1	1	1	0	4
Rijeka	1	1	1	1	1	5
Rovinj	1	0	0	1	0	2
Samobor	1	1	0	1	0	3
Senj	1	1	0	1	0	3
Sinj	0	0	0	1	0	1
Sisak	1	1	1	1	0	4
Skradin	0	0	0	1	0	1
Slatina	1	1	1	0	0	3
Slavonski Brod	1	1	1	1	1	5
Slunj	1	1	1	1	0	4
Solin	1	1	0	1	0	3

GRAD	Godišnje izvršenje proračuna za 2014.	Polugodišnje izvršenje proračuna za 2015.	Prijedlog proračuna za 2016.	Izglasani proračun za 2016.	Proračun za građane za 2016.	OLBI 2016
Split	1	1	1	1	1	5
Stari Grad	0	1	0	1	0	2
Supetar	1	1	1	0	0	3
Sveta Nedelja	1	1	1	1	0	4
Sveti Ivan Zelina	0	0	0	0	0	0
Šibenik	1	1	1	1	1	5
Trilj	0	0	0	1	0	1
Trogir	1	1	1	1	0	4
Umag	1	1	0	1	0	3
Valpovo	0	0	0	1	0	1
Varaždin	1	1	1	1	0	4
Varaždinske Toplice	1	0	1	1	0	3
Velika Gorica	1	1	1	1	0	4
Vinkovci	0	0	0	0	0	0
Virovitica	1	1	1	1	0	4
Vis	0	0	0	1	0	1
Vodice	1	1	1	1	1	5
Vodnjan	0	0	0	1	0	1
Vrbovec	1	1	0	1	0	3
Vrbovsko	0	1	1	1	0	3
Vrgorac	0	0	0	0	0	0
Vrlika	0	0	0	1	0	1
Vukovar	1	1	1	1	0	4
Zabok	1	1	0	1	0	3
Zadar	1	1	1	1	1	5
Zaprešić	1	1	1	1	0	4
Zlatar	1	1	1	1	0	4
Županja	1	1	1	1	1	5

Tablica 2. Podatci o hrvatskim gradovima s varijablama korištenima u radu¹⁴

GRAD	por_prir_po_st	prom_grad	br_st	udio_VO	OLBI
Bakar	3.359,49	0	8.279,00	0,1286	4
Beli Manastir	4.353,57	0	10.068,00	0,1068	0
Belišće	2.626,02	1	10.825,00	0,0827	1
Benkovac	3.352,54	1	11.026,00	0,0459	2
Biograd na Moru	4.353,89	0	5.569,00	0,1323	2
Bjelovar	4.304,74	0	40.276,00	0,1176	5
Buje	3.333,35	0	5.182,00	0,1227	4
Buzet	6.710,65	1	6.133,00	0,1277	5
Cres	6.115,00	0	2.879,00	0,1351	5
Crikvenica	5.953,15	0	11.122,00	0,1607	5
Čabar	3.984,62	1	3.770,00	0,1053	1
Čakovec	4.821,91	1	27.104,00	0,1575	4
Čazma	2.028,98	0	8.077,00	0,0655	1
Daruvar	3.207,83	0	11.633,00	0,1315	3
Delnice	5.838,74	1	5.952,00	0,1336	4
Donja Stubica	2.913,01	0	5.680,00	0,0838	3
Donji Miholjac	2.420,21	1	9.491,00	0,0936	3
Drniš	5.573,99	1	7.498,00	0,0930	4
Dubrovnik	7.207,06	0	42.615,00	0,2169	4
Duga Resa	3.677,01	0	11.180,00	0,1128	5

¹⁴ Oznake varijabli u skladu s tablicom 3.1.

GRAD	por_prir_po_st	prom_grad	br_st	udio_VO	OLBI
Dugo Selo	3.924,50	1	17.466,00	0,0989	3
Đakovo	2.418,65	0	27.745,00	0,0928	1
Đurđevac	2.486,38	1	8.264,00	0,1020	3
Garešnica	2.290,68	0	10.472,00	0,0682	4
Glina	3.575,42	0	9.283,00	0,0568	4
Gospić	6.744,76	1	12.745,00	0,1221	1
Grubišno Polje	2.748,54	0	6.478,00	0,0716	2
Hrvatska Kostajnica	3.785,46	0	2.756,00	0,0809	4
Hvar	5.993,43	1	4.251,00	0,1468	4
Ilok	2.704,11	1	6.767,00	0,0664	0
Imotski	5.213,80	0	10.764,00	0,1165	0
Ivanec	2.888,67	0	13.758,00	0,0893	5
Ivanić-Grad	4.189,81	1	14.548,00	0,0994	4
Jastrebarsko	4.080,01	1	15.866,00	0,0974	4
Karlovac	5.404,65	0	55.705,00	0,1606	5
Kastav	4.794,75	0	10.440,00	0,2036	5
Kaštela	3.345,65	1	38.667,00	0,1149	4
Klanjec	2.916,21	1	2.915,00	0,0679	4
Knin	4.210,74	0	15.407,00	0,0862	1
Komiža	3.587,80	0	1.526,00	0,1016	3
Koprivnica	4.960,90	1	30.854,00	0,1588	5
Korčula	3.940,14	1	5.663,00	0,1598	4
Kraljevica	3.608,27	1	4.618,00	0,1615	2
Krapina	3.912,71	1	12.480,00	0,1218	3
Križevci	3.262,62	0	21.122,00	0,1085	4
Krk	5.969,67	0	6.281,00	0,1536	4
Kutina	4.034,24	1	22.760,00	0,1078	3
Kutjevo	1.531,69	0	6.247,00	0,0571	0
Labin	5.293,32	0	11.642,00	0,1612	5
Lepoglava	3.693,39	0	8.283,00	0,0757	4
Lipik	4.067,42	1	6.170,00	0,0622	4
Ludbreg	3.213,81	1	8.478,00	0,1066	2
Makarska	4.576,74	1	13.834,00	0,1479	4
Mali Lošinj	5.798,85	0	8.116,00	0,1392	5
Metković	2.396,44	1	16.788,00	0,1152	3
Mursko Središće	2.213,21	1	6.307,00	0,0761	2
Našice	3.684,58	0	16.224,00	0,1124	1
Nin	3.167,54	0	2.744,00	0,0915	0
Nova Gradiška	3.464,00	1	14.229,00	0,1048	2
Novalja	5.599,27	1	3.663,00	0,1002	2
Novi Marof	2.528,25	0	13.246,00	0,0744	2
Novi Vinodolski	4.169,96	0	5.113,00	0,1334	3
Novigrad	4.531,61	0	4.345,00	0,1211	4
Novska	4.722,40	1	13.518,00	0,0607	3
Obrovac	4.080,46	0	4.323,00	0,0694	1
Ogulin	5.010,04	1	13.915,00	0,1064	4
Omiš	3.659,34	1	14.936,00	0,1083	3
Opatija	7.790,75	0	11.659,00	0,2387	5
Opuzen	2.081,32	0	3.254,00	0,1260	3
Orahovica	4.901,03	0	5.304,00	0,1188	4
Oroslavje	3.929,72	0	6.138,00	0,1064	1
Osijek	5.490,23	1	108.048,00	0,1783	5
Otočac	4.842,95	1	9.778,00	0,0817	2
Otok (Vinkovci)	3.218,79	0	6.343,00	0,0378	1
Ozalj	3.924,10	1	6.817,00	0,0681	5
Pag	3.692,00	1	3.846,00	0,1253	1
Pakrac	4.738,70	0	8.460,00	0,0809	3
Pazin	4.356,66	0	8.638,00	0,1475	5

GRAD	por_prir_po_st	prom_grad	br_st	udio_VO	OLBI
Petrinja	5.480,57	1	24.671,00	0,0932	3
Pleternica	1.806,06	1	11.323,00	0,0508	0
Ploče	2.938,08	0	10.135,00	0,1375	2
Popovača	2.694,46	0	11.905,00	0,0605	1
Poreč	5.577,58	0	16.696,00	0,1537	5
Požega	4.079,79	1	26.248,00	0,1325	3
Pregrada	3.309,08	1	6.594,00	0,0549	4
Prelog	2.293,87	1	7.815,00	0,0769	3
Pula	5.781,90	0	57.460,00	0,1792	5
Rab	4.670,92	1	8.065,00	0,1061	4
Rijeka	6.728,93	0	128.624,00	0,2102	5
Rovinj	7.182,39	0	14.294,00	0,1680	2
Samobor	7.233,14	0	37.633,00	0,1460	3
Senj	5.980,22	0	7.182,00	0,1111	3
Sinj	5.310,97	0	24.826,00	0,1009	1
Sisak	4.870,37	1	47.768,00	0,1336	4
Skradin	4.305,75	0	3.825,00	0,0379	1
Slatina	2.535,88	0	13.686,00	0,0892	3
Slavonski Brod	4.307,56	0	59.141,00	0,1269	5
Slunj	4.697,54	1	5.076,00	0,0615	4
Solin	3.511,17	0	23.926,00	0,1213	3
Split	5.836,38	1	178.102,00	0,2198	5
Stari Grad	3.121,20	1	2.781,00	0,1176	2
Supetar	5.934,64	1	4.074,00	0,1443	3
Sveta Nedelja	8.336,25	0	18.059,00	0,1211	4
Sveti Ivan Zelina	3.370,59	1	15.959,00	0,0748	0
Šibenik	4.767,43	1	46.332,00	0,1524	5
Trilj	3.799,42	0	9.109,00	0,0445	1
Trogir	3.908,20	1	13.192,00	0,1316	4
Umag	5.168,16	0	13.467,00	0,1455	3
Valpovo	2.923,54	0	11.563,00	0,0967	1
Varaždin	6.416,14	1	46.946,00	0,2021	4
Varaždinske Toplice	2.749,28	1	6.364,00	0,0842	3
Velika Gorica	6.178,14	0	63.517,00	0,1299	4
Vinkovci	4.288,53	0	35.312,00	0,1292	0
Virovitica	3.685,93	0	21.291,00	0,1162	4
Vis	4.542,62	0	1.934,00	0,1396	1
Vodice	4.125,65	0	8.875,00	0,1177	5
Vodnjan	3.714,46	0	6.119,00	0,0914	1
Vrbovec	3.238,24	0	14.797,00	0,0856	3
Vrbovsko	5.386,75	1	5.076,00	0,0885	3
Vrgorac	4.396,85	0	6.572,00	0,0802	0
Vrlika	3.681,38	0	2.177,00	0,0436	1
Vukovar	4.909,37	0	27.683,00	0,1244	4
Zabok	4.186,30	0	8.994,00	0,1302	3
Zadar	5.340,52	1	75.062,00	0,1898	5
Zaprešić	7.027,57	0	25.223,00	0,1639	4
Zlatar	3.055,15	1	6.096,00	0,0746	4
Županja	3.486,17	0	12.090,00	0,1129	5

Sažetak

Proračuni lokalnih jedinica su jedan od najvažnijih izvora informacija koji daje širu sliku o financijskom stanju tih jedinica, te koji može poslužiti kao mjera nadzora odluka lokalnih političkih vlasti. U radu se analiziraju odrednice proračunske transparentnosti 127 hrvatskih gradova. Provodi se Poissonova regresija kako bi se ispitalo utječe li udio visokoobrazovanih, broj stanovnika, porez i prirez na dohodak po zaposlenom stanovniku te reizbor gradonačelnika na proračunsku transparentnost hrvatskih gradova. Dobiveni rezultati ukazuju da od svih izabranih varijabli samo udio visokoobrazovanih osoba pozitivno i statistički značajno utječe na proračunsku transparentnost.

Summary

Budgets of local government units are one of the most important sources of information that can give the bigger picture of financial situation of those units and can serve as a measure of supervision of policy makers. This thesis analyses the budget transparency and the possible effects of chosen variables. Poisson regression has been used on the sample of 127 Croatian cities to determine if chosen variables – share of citizens with university education, personal income tax and surtax, re-election of a mayor and number of citizens – have an effect on budget transparency. Results indicate that only the share of citizens with university education has positive and statistically significant effect.

Životopis

Magdalena Šimac rođena je 5. lipnja 1991. u Zagrebu gdje, na istoj adresi – u Kušlanovoj ulici, pohađa i osnovnu i srednju školu. Potom upisuje preddiplomski studij Matematike na Prirodoslovno-matematičkom fakultetu. 2014. godine postaje sveučilišna prvostupnica matematike i ubrzo odabire diplomski studij Financijske i poslovne matematike kao nastavak školovanja na istom fakultetu. Tokom svog akademskog obrazovanja povremeno obavlja različite studentske poslove, a u slobodno vrijeme bavi se orijentalnim plesom. Nakon završetka diplomskog studija 2017., počinje raditi kao analitičarka u odjelu revizije u tvrtki Deloitte u Zagrebu.